

Marta Woźniak

# Przegląd algorytmów ewolucyjnych i ich zastosowań

## 1. Wstęp

W ciągu ostatnich dziesięcioleci można zauważyć wzrost zainteresowania systemami wykorzystującymi sztuczną inteligencję w celu rozstrzygania różnego typu problemów. Sztuczna inteligencja definiowana jest jako dziedzina informatyki zajmująca się problematyką systemów komputerowych, które są zdolne do przyswajania, analizowania, a także do wykorzystywania zaistniałych faktów i wiedzy rozumianej jako informacja przydatna do pozyskiwania nowych faktów [10]. Algorytmy ewolucyjne, których działanie w sztucznym środowisku naśladuje procesy powstawania kolejnych pokoleń w środowisku naturalnym, i związane z nimi obliczenia to dział sztucznej inteligencji [8, 9, 13].

W związku z rozwojem prac nad tymi zagadnieniami należy rozważyć, w jakich sytuacjach uzasadnione staje się stosowanie algorytmów genetycznych w informatyce, automatyce. W tym celu zostanie dokonany przegląd algorytmów ewolucyjnych. Następnie w kolejnej części artykułu przedstawione zostaną zastosowania algorytmów genetycznych w konkretnych przypadkach z zakresu wymienionych wcześniej dziedzin.

## 2. Przegląd algorytmów ewolucyjnych

Czym jest ewolucja? Chyba najlepiej określa to słowa Karola Darwina: „Jakże zajmujące jest spoglądać na gęsto zarośnięte wybrzeże pokryte roślinami należącymi do różnych gatunków, ze śpiewającym ptactwem w gąszczach, z krążącymi w powietrzu owadami, z drążącymi mokłą glebę robakami i patrzeć na te wszystkie tak dziwnie zbudowane formy, tak różne i w tak złożony sposób od siebie zależne. Pomyśleć, że powstały one na skutek praw wciąż jeszcze wokół nas działających. Prawami tymi w najszerszym znaczeniu są: wzrost i rozmnażanie, zawarta prawie w pojęciu rozmnażania dziedziczność, zmienność pod bezpośrednim i pośrednim

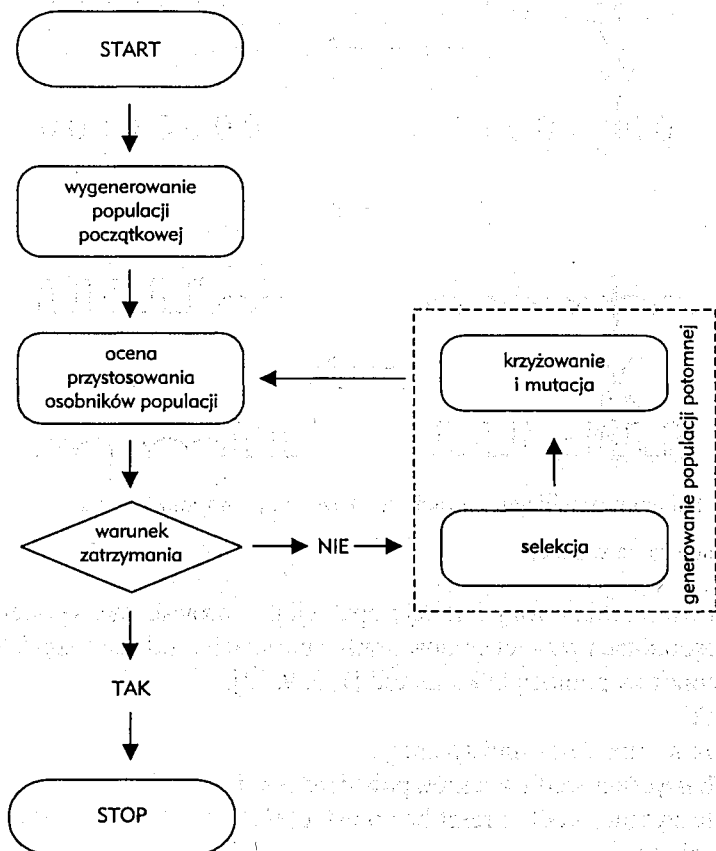
wpływem zewnętrznych warunków życia oraz używanie i nieużywanie narządów do walki o byt i w konsekwencji do doboru naturalnego, który ze swej strony prowadzi do rozbieżności cech i wymierania form mniej udoskonalonych. Tak więc z walki w przyrodzie, z głodu i śmierci bezpośrednio wynika najwznioślejsze zjawisko, jakie możemy pojąć, a mianowicie powstawanie wyższych form zwierzęcych. Wzniosły zaiste jest to pogląd, że Stwórca natchnął życiem kilka form lub jedną tylko, i że gdy planeta nasza, podlegając ścisłym prawom ciężenia, dokonywała swych obrotów, z tak prostego początku zdołał się rozwinąć i wciąż jeszcze rozwija nieskończony szereg form najpiękniejszych i najbardziej godnych podziwu" [11]. Tymi słowami kończy się opracowanie pt. *O powstawaniu gatunków*, ogłoszone w roku 1859, w którym Karol Darwin przedstawił teorię ewolucji przez dobór naturalny. Teoria ta stanowi źródło do naśladowania przy rozstrzyganiu problemów w różnych dziedzinach nauki. Należy podkreślić, że na mechanizmach ewolucji (np. selekcji, krzyżowaniu, mutacji i reprodukcji) oparte są algorytmy ewolucyjne.

Algorytmami ewolucyjnymi nazywamy techniki przeszukiwania przestrzeni rozwiązań, rozwijane przez kilku dziesięcioleci. Najpopularniejsze z nich to: algorytmy genetyczne, stworzone przez Johna Hollanda [4] w Stanach Zjednoczonych Ameryki Północnej, spopularyzowane przez Davida Goldberga [3], a także programowanie genetyczne, rozwijane przez Johna Kożę [7]. Kolejne dwie techniki to programowanie ewolucyjne, nad którym pracował Lawrence Fogel [2] oraz strategie ewolucyjne, którymi zajmowali się Ingo Rechenberg [15] i Hans-Paul Schwefel [16].

Aby móc swobodnie mówić o algorytmach ewolucyjnych, należy przyswoić sobie wiedzę na temat terminologii zaczerpniętej z genetyki. Do pojęć tych należą m.in. chromosom, który jest ciągiem uporządkowanych jednostek elementarnych zwanych genami. Zespół chromosomów to genotyp, z kolei jego niezakodowany odpowiednik to fenotyp. Wartość genu to po prostu allel, a jego miejsce położenia w chromosomie to locus. Przestrzeń, w której działa algorytm nazywana jest populacją i składa się z osobników, których cechy określone są poprzez zapis w postaci genotypu. Aby wszystko było zgodne z teorią ewolucji, potrzebny jest jeszcze element, który pozwoli na określenie stopnia przystosowania osobników, co w dalszym etapie pozwoli na przetrwanie lepiej przystosowanych i tym samym wyeliminowanie słabszych jednostek. Kolejne pokolenia osobników powstają dzięki selekcji, krzyżowaniu oraz mutacji.

Zadaniem algorytmu genetycznego jest modelowanie procesu poprzez naśladowanie naturalnego przebiegu ewolucji. Cały proces w uproszczeniu można przedstawić za pomocą schematu blokowego (rys. 1). Zgodnie z tym schematem na początku zostaje stworzona populacja bazowa, zwana także populacją początkową lub rodzicielską. Populacja ta generowana jest losowo. Kolejnym krokiem jest ocena przystosowania osobników rodzicielskich. Następnie sprawdzany jest warunek zatrzymania. W przypadku gdy warunek zatrzymania nie jest spełniony, następuje tzw. selekcja i wybór osobników do reprodukcji. Oznacza to, że nie wszystkie jed-

nostki w populacji mają taką samą szansę na udział w reprodukcji. Jedynie te osobniki, dla których funkcja przystosowania przyjmuje większe wartości, mogą „przejsć do następnego etapu” ewolucji. Na tym etapie zachodzi krzyżowanie i mutacja. Następnie oceniane jest przystosowanie nowego pokolenia (generacji), powstałego w procesach mutacji i krzyżowania i jednocześnie zaczyna się kolejny obieg pętli algorytmu.

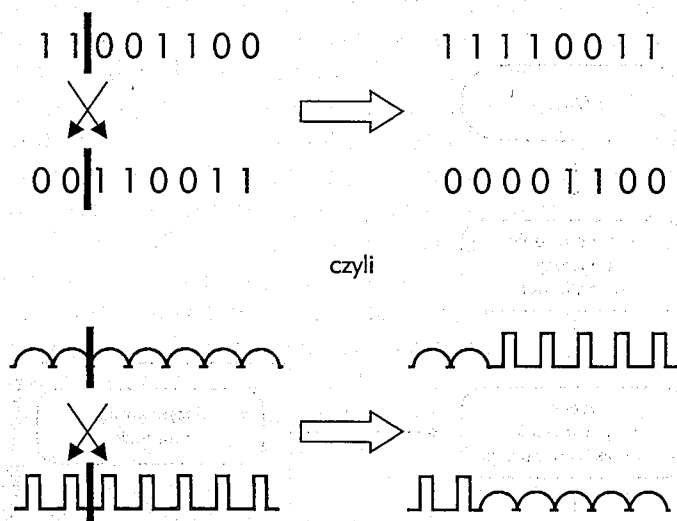


Rysunek 1. Schemat działania algorytmu genetycznego

Źródło: opracowanie własne.

Już od samego początku pojawiać się mogą problemy – np. ze sposobem kodowania osobników. Najpopularniejszy jest kod binarny. Jedynie, o czym należy pamiętać, to ustalenie wystarczającej liczby bitów, za pomocą których zakodowana zostanie informacja. Istnieją dwie zasady umożliwiające dokonanie wyboru odpowiedniego kodu. Zasady te podaje D. Goldberg [3].

W trakcie projektowania należy także określić funkcję przystosowania, która pozwoli, tak jak to się dzieje w środowisku organizmów żywych, na przetrwanie silniejszych i lepiej przystosowanych osobników przy jednoczesnej eliminacji gorszych rozwiązań.



czyli

Rysunek 2. Schemat przebiegu operacji krzyżowania jednopunktowego

Źródło: opracowanie własne.

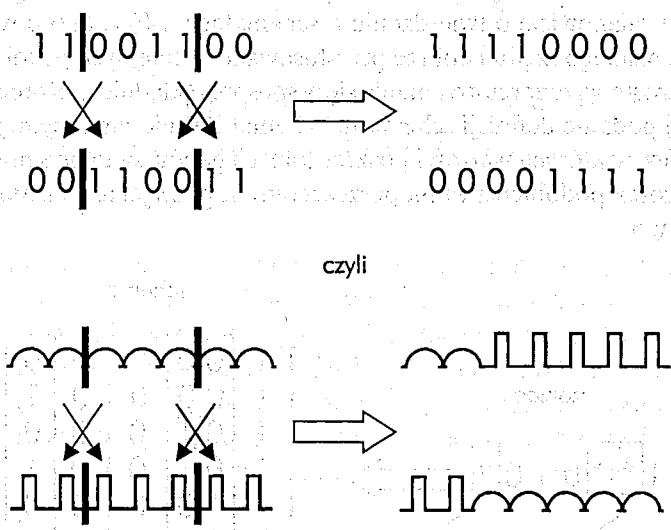
W celu stworzenia nowej, lepszej populacji przeprowadzane są operacje genetyczne na osobnikach wyselekcjonowanych z populacji „rodzicielskiej”. Selekcji tej można dokonać za pomocą kilku metod [1, 3, 9, 13]:

- ruletki,
- próbkowania deterministycznego,
- stochastycznej według reszt z powtórzeniami,
- stochastycznej według reszt bez powtórzeń,
- turniejowej,
- rankingowej.

Metoda ruletki jest najczęściej stosowana w praktyce i polega na utworzeniu koła ruletki ze zsumowanych wartości funkcji przystosowania poszczególnych rozwiązań. Osobniki, którym przypisywany jest wycinek koła proporcjonalny do ich wartości funkcji przystosowania, zostają losowane do następnej populacji zgodnie z zasadami gry w ruletkę. Następne trzy metody polegają na obliczeniu oczekiwanej liczby potomków dla każdego osobnika. Te trzy metody różnią się sposobem wyboru osobników, które uzupełnią nową populację. Ma to na celu zachowanie

liczebności populacji w kolejnych cyklach. W metodzie turniejowej wybrane osobniki „konkurują” ze sobą i do następnej populacji przechodzi lepszy z nich. Z kolei w metodzie rankingowej liczba potomków zależy od rangi osobnika.

Wyselekcjonowane osobniki poddawane są operacjom krzyżowania i mutacji. Podczas krzyżowania dochodzi do wymiany fragmentów genotypów pomiędzy dwoma osobnikami. W zależności od liczby miejsc przecięcia genotypu, czyli sposobu podzielenia genotypu na części, krzyżowanie dzieli się na jedno- i wielopunktowe. Krzyżowanie jednopunktowe przedstawia rysunek 2. Natomiast krzyżowanie wielopunktowe (dwupunktowe) przedstawiono na rysunku 3.




czyli

Rysunek 3. Schemat przebiegu operacji krzyżowania wielopunktowego (dwupunktowego)

Źródło: opracowanie własne.

Mutacja z kolei polega na wymianie wartości bitu z 0 na 1 lub odwrotnie. Przykład działania mutacji ilustruje rysunek 4.



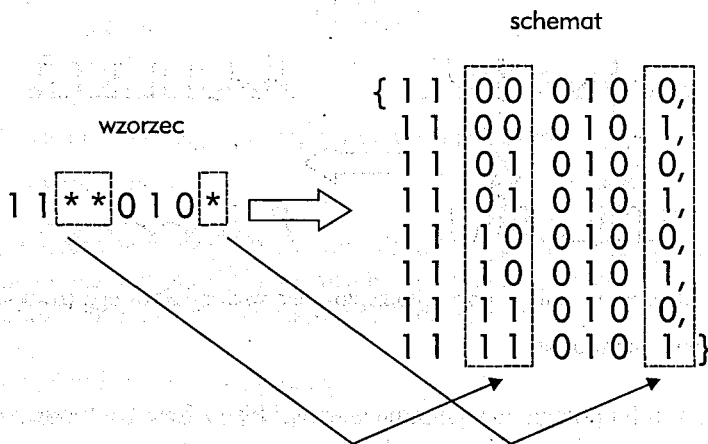
Rysunek 4. Schemat przebiegu mutacji

Źródło: opracowanie własne.

Po operacjach genetycznych następuje powrót do oceny przystosowania nowej generacji osobników i sprawdzenie warunku zatrzymania.

Ustalenie warunku zatrzymania algorytmu sprawia wiele trudności, dlatego też opracowane zostały specjalne kryteria. Najczęściej stosowanymi kryteriami są kryterium zadowalającego poziomu funkcji przystosowania oraz minimalnej szybkości poprawy. W pierwszym z nich zatrzymanie algorytmu następuje po osiągnięciu zadanej przez projektanta wartości funkcji przystosowania, z kolei w drugim algorytm zatrzymuje się, gdy w określonej przez projektanta liczbie generacji nie nastąpi poprawa rozwiązania o również określoną przez projektanta wartość.

Należy wspomnieć tutaj o podstawowym twierdzeniu w teorii algorytmów genetycznych, a mianowicie o twierdzeniu o schematach. Mówi ono o tym, że schematy wąskie, niskiego rzędu i dobrze przystosowane w kolejnych pokoleniach mają tendencję wzrostową rozprzestrzeniania się w sposób wykładniczy. Koniecznym staje się więc tutaj podanie definicji schematu. Schemat jest niczym innym, jak zbiorem chromosomów, w których wartości poszczególnych genów są takie same jak wartości genów wzorca podobieństwa na poszczególnych pozycjach. Zostało to pokazane na rysunku 5.



Rysunek 5. Wzorec i schemat z ośmioma możliwymi kombinacjami ułożenia genów w chromosomach zgodnie ze wzorcem

Źródło: opracowanie własne.

Rzędem schematu jest liczba zer i jedynek w schemacie, czyli liczba genów o wartości różnej od znaku „\*”, czyli znaku, pod którym kryć się może albo 0, albo 1. Z kolei rozpiętość schematu to różnica między skrajnymi położeniami wartości wzorca różnych od „\*”, czyli położeniami genów zawierających 0 lub 1. Określanie rzędu i rozpiętości zostało pokazane na rysunku 6.

	rzqd schematu	rozpiętość schematu
1 * * 1 1 * 0	4	$7 - 1 = 6$
* 1 * * * * 0	2	$7 - 2 = 5$
1 * 0 * * * *	2	$3 - 1 = 2$
0 * * * * 1 1	3	$7 - 1 = 6$
* 0 1 0 1 0 1	6	$7 - 2 = 5$

Rysunek 6. Przykłady określania rzędu i rozpiętości schematu

Źródło: opracowanie własne.

Z twierdzenia o schematach wywodzi się tzw. hipoteza cegiełek. Mówi ona o tym, że algorytmy genetyczne działają, opierając się na składaniu ciągów genów, zwanych cegiełkami. Istotne jest, aby geny w chromosomach układane były w taki sposób, aby te umiejscowione blisko siebie były wzajemnie od siebie zależne. W ten sposób cegiełki złożone z ciągów genów obarczonych pewnymi zależnościami względem siebie tworzą nową populację, w której nowe osobniki dzięki powiązaniom między grupami genów przenoszą coraz to wartościowsze informacje.

### 3. Zastosowania algorytmów genetycznych

Algorytmy genetyczne mogą być wykorzystywane do rozwiązywania problemu komiwojażera lub też problemu transportowego. W przypadku problemu komiwojażera jest to szczególnie uzasadnione, ponieważ problem ten należy do tzw. problemów NP-trudnych, czyli wraz ze wzrostem liczby miast, które musiałby on pokonać, wykładniczo rośnie także czas potrzebny do znalezienia rozwiązania [18]. Polega to na tym, że do rozwiązania tego problemu wystarczy jedynie obliczyć permutacje wszystkich miast, a także sumę odległości między miastami dla poszczególnych permutacji. Następnie należy porównać otrzymane wyniki i wybrać najkrótszą trasę. Z pozoru jest to bardzo proste i dla małej liczby miast szybko można rozstrzygnąć tego typu zagadnienie. Co jednak zrobić, gdy na trasie komiwojażera pojawi się 20 lub 40 miast? Znacznie zwiększa się czas obliczeń. Zastosowanie algorytmu genetycznego, w którym każda trasa to jeden osobnik, przy zastosowaniu krzyżowania (wymiany odcinków trasy), mutacji, a także selekcji i funkcji przystosowania

umożliwia stosunkowo szybko uzyskanie najkrótszej trasy [18]. Problem transportowy z kolei polega na dostarczaniu towaru różnorodnego bądź też jednego rodzaju z kilku punktów nadania do kilku punktów odbioru. Odbywa się to w taki sposób, aby zamówione ilości towaru dotarły np. z magazynów do sklepów z uwzględnieniem zapasów towarów w magazynach i odległości magazynów od sklepów. W tym przypadku również należy zminimalizować koszty transportu. Zostało to szerzej opisane w [17], gdzie podano także wyniki badań, na podstawie których można stwierdzić, że algorytmy genetyczne generują lepsze rozwiązania (niższe koszty) niż metoda planowania wcześniej wykorzystywana przez badaną firmę. Algorytmy genetyczne można również wykorzystywać np. w automatyce, mechanice i hydraulice. Znany jest przypadek wykorzystywania algorytmu ewolucyjnego w elastycznych systemach produkcyjnych, szczególnie w odniesieniu do sterowania operacyjnego [12]. Przypadek zastosowania algorytmów genetycznych w mechanice konstrukcji został opisany w [14]. Przedstawiono tam zastosowanie algorytmów genetycznych do rozwiązywania problemów bezpośrednich, optymalizacji powłoki chłodni kominowej oraz identyfikacji w układach mechanicznych. Podejmowane są także próby zastosowania algorytmu genetycznego do projektowania układów hydraulicznych. Można też spotkać się z zastosowaniem algorytmów genetycznych do szeregowania zadań i rozdziału zasobów występujących w sieciach i systemach komputerowych, a także w systemach produkcyjnych [5, 6]. Algorytmy genetyczne mogą być również wykorzystywane w odniesieniu do problemów związanych z działami gospodarki. Praktyczne przykłady takiego zastosowania przedstawione są w artykule „Gospodarcze zastosowanie algorytmów genetycznych”.

## 4. Wnioski końcowe

Jak widać, możliwości wykorzystania algorytmów ewolucyjnych, w tym algorytmów genetycznych, są bardzo szerokie. Składa się na to m.in. prostota pojęciowa tych algorytmów. Cechą charakterystyczną tych algorytmów jest także to, że poszukując rozwiązania wychodzą z określonej populacji, a nie z jednego punktu, jak to się dzieje w przypadku tradycyjnych metod, a także to, że korzystają z funkcji celu, a nie jej pochodnych [3].

Algorytmy genetyczne znajdują zastosowanie wszędzie tam, gdzie użycie powszechnych metod analitycznej i enumeracyjnej jest niepraktyczne np. ze względu na długi czas obliczeń bądź też zbyt trudnych do spełnienia założeń. Tak więc algorytm genetyczny jest metodą optymalizacji globalnej łatwą do implementacji w szerokiej gamie problemów.



## Bibliografia

- [1] Arabas J., *Wykłady z algorytmów ewolucyjnych*, Warszawa 2001.
- [2] Fogel L., Owens A., Walsh M., *Artificial intelligence through simulated evolution*, Chichester 1966.
- [3] Goldberg D.E., *Algorytmy genetyczne i ich zastosowania*, Warszawa 2003.
- [4] Holland J.H., *Adaptation in natural and artificial systems*, Michigan 1975.
- [5] Janiak A., Kobyłański P., *Algorytm genetyczny rozwiązujący przepływowy problem obsługi z zasobami*, „Zeszyty Naukowe Politechniki Śląskiej”, „Automatyka” 1994, z. 114, s. 99–109.
- [6] Janiak A., *Wybrane problemy i algorytmy szeregowania zadań i zasobów*, Warszawa 1999.
- [7] Koza J.R., *Genetic Programming: A Paradigm for genetically Breeding Populations of Computer Programs to Solve Problems*, report nr. STAN-CS-90-1314, Stanford 1990.
- [8] Kwaśnicka H., *Obliczenia ewolucyjne w sztucznej inteligencji*, Wrocław 1999.
- [9] Kwaśnicka H., *Sztuczna inteligencja. Algorytmy ewolucyjne – przykłady zastosowań*, Wrocław 2002.
- [10] Kwaśniewski J., *Programowalne sterowniki przemysłowe w systemach sterowania*, Kraków 1999.
- [11] Larousse, *Ziemia. Rośliny. Zwierzęta*, tłum. J. Wernerowa, J. Żabiński, Warszawa 1990.
- [12] Łebkowski P., *Planowanie montażu mechanicznego w elastycznych systemach produkcyjnych*, Kraków 2002.
- [13] Michalewicz Z., *Algorytmy genetyczne + struktury danych = programy ewolucyjne*, Warszawa 1999.
- [14] Pieczara J., *Algorytmy genetyczne w mechanice konstrukcji*, Kraków 2004.
- [15] Rachenberg I., *Evolutionsstrategie: Optimierung technischer Systeme nach Prinzipien der biologischen Evolution*, Stuttgart 1973.
- [16] Schwefel H.P., *Evolution and optimum seeking*, Chichester 1995.
- [17] Załuski T., *Wykorzystanie programowania liniowego oraz algorytmów genetycznych do rozwiązywania liniowych zadań optymalizacyjnych z ograniczeniami*, Kraków 2004.
- [18] <http://www.republika.pl/k0pper>.